

Marcos Vinícius dos Santos Ferreira

**Metodologia automatica para diagnostico do
glaucoma usando abordagem *Deep Learning***

Picos - PI
13 de Novembro de 2017

Marcos Vinícius dos Santos Ferreira

**Metodologia automatica para diagnostico do glaucoma
usando abordagem *Deep Learning***

Monografia submetida ao Curso de Bacharelado em Sistemas de Informação como requisito parcial para obtenção de grau de Bacharel em Sistemas de Informação. Orientadora: Profa. Ma. Alcilene Dalília de Sousa

Universidade Federal do Piauí
Campus Senador Heuvídio Nunes de Barros
Bacharelado em Sistemas de Informação

Picos - PI
13 de Novembro de 2017

FICHA CATALOGRÁFICA
Serviço de Processamento Técnico da Universidade Federal do Piauí
Biblioteca José Albano de Macêdo

F383m Ferreira, Marcos Vinícius dos Santos.

Metodologia automática para diagnóstico do glaucoma usando abordagem *Deep Learning* / Marcos Vinícius dos Santos Ferreira.– 2017.

CD-ROM : il.; 4 ¾ pol. (27 f.)

Trabalho de Conclusão de Curso (Curso Bacharelado em Sistemas de Informação) – Universidade Federal do Piauí, Picos, 2018.

Orientador(A): Prof^a. Ma. Alcilene Dalília de Sousa

· Imagens Médicas. 2. Glaucoma. 3. *Convolutional Neural Network*. II. Título

CDD 005.188

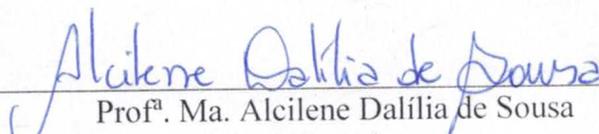
METODOLOGIA AUTOMÁTICA PARA DIAGNÓSTICO DO GLAUCOMA USANDO
ABORDAGEM DEEP LEARNING

MARCOS VINICIUS DOS SANTOS FERREIRA

Monografia aprovada como exigência parcial para obtenção do grau de
Bacharel em Sistemas de Informação.

Data de Aprovação

Picos – PI, 05 de dezembro de 20 17


Profª. Ma. Alcilene Dalília de Sousa
Orientador


Prof. Dr. Antonio Oséas de Carvalho Filho
Membro


Prof. Esp. Ismael de Holanda Leal
Membro

Agradecimentos

Agradeço primeiramente a Deus por conceder a realização deste trabalho. A Ele, toda a gratidão. Aos meus pais, Josué Ferreira e Maria da Paz dos Santos Ferreira por ser a base de tudo, pelo incentivo e trabalho de ambos cheguei até aqui.

A minha irmã Myrian Vanessa.

À UFPI pelo apoio durante os 4 anos de curso. A minha orientadora Profa. Ma. Alcilene Dalília de Sousa por me guiar desde o início da minha formação perante o estudo e a pesquisa. Obrigado pela positividade, paciência e ensinamentos transmitidos e pelo grande exemplo de determinação oferecendo oportunidades de crescimento acadêmico.

Ao Profo. Dr. Antonio Oseas de Carvalho Filho pelo incentivo, disposição e presteza no auxílio às atividades e discussões sobre o andamento deste trabalho auxiliando a obter resultados significativos na pesquisa.

As Profa. Ma. Patricia Medyna Lauritzen de Lucena Drumond e Profa. Ma. Patricia Vieira da Silva Barros pela disponibilidade e disposição a ajudar-me, meus eternos agradecimentos.

Aos meus professores de graduação, muito obrigado.

Aos meus amigos Edson Damasceno, Marcelo Damasceno, Vitorio Silva, Antônio Carvalho e Kelly Maria pelo apoio e esclarecimentos nas horas difíceis em que estavam dispostos a ajudar e a aconselhar.

Por fim, a todos que, de forma direta ou indireta, contribuíram à realização deste sonho.

*Envelhecer, qualquer animal é capaz. Desenvolver-se é prerrogativa dos seres humanos.
Somente uns poucos reivindicam esse direito...*

(Osho)

Resumo

O Glaucoma é uma doença assintomática causada por lesão do nervo óptico em decorrência do aumento elevado da pressão intra-ocular. Com o diagnóstico precoce, as chances de controlar sua progressão são maiores. O glaucoma é um grande problema na saúde mundial como causa de cegueira, perdendo apenas para a catarata. Este trabalho apresenta o desenvolvimento de um método para a detecção automática do glaucoma em imagens da retina utilizando uma abordagem de aprendizado profundo. A metodologia utilizada no trabalho foi aquisição de imagens, treinamento da rede neural convolucional para detecção do disco óptico, extração dos vasos sanguíneos e extração de características baseadas na textura. Por fim, foi realizada a classificação utilizando redes neurais convolucionais alcançando uma acurácia de 98.5%.

Palavras-chaves: Imagens Médicas; Glaucoma; Rede Neural Convolucional; Índice de diversidade filogenética.

Abstract

Glaucoma is an asymptomatic disease caused by optic nerve damage due to elevated intraocular pressure. With early diagnosis, the chances of controlling your progression are greater. Glaucoma is a major health problem worldwide as a cause of blindness, only losing to the cataract. This paper presents the development of a method for the automatic detection of glaucoma in retinal images using a deep learning approach. The methodology used in the work was image acquisition, convolutional neural network training for detection of the optic disc, extraction of the blood vessels and extraction of characteristics based on the texture. Finally, classification was performed using convolutional neural networks reaching an accuracy of 98.5%.

Palavras-chaves: Medical Images; Glaucoma; Convolutional Neural Network; Phylogenetic Diversity Index.

Lista de ilustrações

Figura 1 – Fluxograma da metodologia proposta.	15
Figura 2 – Representação da arquitetura U-net.	17
Figura 3 – Detecção do DO.	22

Lista de tabelas

Tabela 1 – Comparação com os trabalhos relacionados	23
---	----

Lista de abreviaturas e siglas

A	Acurácia
CAD	Computer-Aided Detection
CADx)	Computer-Aided Diagnostic
CNN	Convolutional Neural Network
CO	Copo Óptico
DO	Disco Óptico
DL	Deep Learning
GB	Gigabytes
HRT	Heidelberg Retina Tomography
MNND	Phylogenetic Distances
SPD	Mean Nearest Neighbour Distance
PD	Phylogenetic Diversity
PSR	Phylogenetic Species Richness
PSV	Phylogenetic Species Variability
OCT	Optical Coherence Tomography
PIO	Pressão Intra-Ocular
ReLU	Rectified Linear Units
ROI	Regiões de Interesse

Sumário

1	Introdução	12
2	Trabalhos Relacionados	13
3	Materiais e Métodos	15
3.1	Aquisição de Imagens	16
3.2	Convolutional Neural Netowrk	16
3.3	Treinamento	17
3.4	Extração dos Vasos Sanguíneos	18
3.5	Extração de Características	19
3.6	Classificação	20
3.7	Validação dos Resultados	20
4	Resultados e Discussões	21
4.1	Configuração dos Testes	21
4.2	Resultados dos Testes	21
5	Conclusão	24
6	Publicações	25
	Referências	26

1 Introdução

O glaucoma é uma doença crônica assintomática que devido ao aumento da Pressão Intra-Ocular (PIO) elevada, causa dano ao nervo óptico levando a perda periférica irreversível ou total da visão (LAMANI et al., 2014; YADAV; SARATHI; DUTTA, 2014). O nervo óptico é a parte do olho que transmite a informação visual da retina até o cérebro. Com o nervo óptico lesionado, causa um maior alargamento da escavação ou Copo Óptico-(CO), se comparado ao alargamento do Disco Óptico-(DO).

O glaucoma não possui cura e quanto mais cedo o paciente for diagnosticado, menor são as chances de sofrer com os efeitos da doença, uma vez que, o tratamento precoce retardará a evolução da mesma. (AGARWAL et al., 2015). O glaucoma está entre as principais causas de cegueira do mundo, atingindo aproximadamente 66,8 milhões de pessoas, e estimando que 10% desta população torna-se cega de ambos os olhos devido a esta doença, sendo um grande problema na saúde mundial ficando atrás apenas para catarata (YIN et al., 2012).

Para o diagnóstico, pode ser feito tanto o exame clínico por um oftalmologista como a tonometria, que é um exame oftalmológico que permite a medida PIO, ou usando equipamentos caros especializados como a *Optical Coherence Tomography* (OCT), e *Heidelberg Retina Tomography* (HRT) (BURGOYNE et al., 2005). O OCT é um exame não invasivo que mede a espessura da camada de fibra nervosa da retina, feito através uma tecnologia especial que cria imagens seccionais dos tecidos. O HRT é um scanner a laser confocal que realiza a aquisição e análise de imagens tridimensionais do nervo óptico para detecção de lesões glaucomatosas. No entanto, a avaliação do DO por um oftalmologista é subjetiva e a disponibilidade dos exames OCT e HRT precisam de mão de obra especializada, e possuem um custo elevado (LIU et al., 2011).

Uma alternativa viável a esses exames são os *Computer-Aided Detection* (CAD) / *Computer-Aided Diagnostic* (CADx). Esses sistemas são ferramentas computacionais para auxiliar e melhorar os diagnósticos médicos através de imagens. Assim os CAD e CADx tem por objetivo aumentar a precisão do diagnóstico, proporcionando ao especialista uma segunda opinião, uma vez que informações adicionais resultam em um diagnóstico mais preciso. Assim, neste trabalho foi desenvolvido um sistema CAD/CADx para diagnóstico automático do glaucoma contribuindo para um diagnóstico mais acessível (RONNEBERGER; FISCHER; BROX, 2015; OLIVEIRA et al., 2015). Para isso, é utilizado uma arquitetura de *Deep Learning*, a *Convolutional Neural Network* (CNN) para detectar as Regiões de Interesse (ROIs) sobre imagens da retina. Em etapas posteriores, são extraídas as características das ROIs utilizando descritores baseados em textura. Por fim são classificadas as informações obtidas com os descritores para quantificação do glaucoma e avaliar o método proposto.

2 Trabalhos Relacionados

Nesta seção, serão abordados trabalhos que trazem em sua metodologia um mecanismo de auxílio no diagnóstico do glaucoma utilizando técnicas de Processamento Digital de Imagens (PDI), *Deep Learning*, e Reconhecimento de Padrões.

Em (CHEN et al., 2015) os autores desenvolvem uma arquitetura de CNN para ser capaz de capturar as características discriminativas que melhor caracterizam os padrões ocultos relacionados ao glaucoma. A estrutura *Deep Learning* adotada contém seis camadas: quatro camadas convolucionais e duas camadas totalmente conectadas. A saída da última camada totalmente conectada é alimentada para um classificador *soft-max* para a previsão do glaucoma. Os resultados mostram a área sob curva ROC de 0.831 e 0.887.

No trabalho de(SEVASTOPOLSKY, 2017) é apresentada uma abordagem para a segmentação automática do DO e CO que se baseia em *Deep Learning* utilizando uma modificação da arquitetura de CNN U-Net. O método atinge qualidade comparável aos atuais métodos de última geração para a segmentação do DO e CO, superando-os em termos de tempo de previsão. Os resultados mostram que a segmentação automática do DO pode ser feita com qualidade comparativa com o humano, entretanto o CO é mais complexo para reconhecer.

Em (ORLANDO et al., 2017) os autores realizam a análise da viabilidade do uso de CNN que são pré-treinados a partir de dados não médicos para a detecção automatizada de glaucoma. Duas CNNs diferentes pré-treinadas, foram aplicadas em imagens de fundo para afinar os pesos dessa rede, para ter um classificador explicitamente dedicado à nova tarefa de detectar o DO e CO. Os resultados no conjunto de dados Drishti-GS1, avaliados em termos de área sob a curva ROC média, sugerem a viabilidade desta abordagem e oferecem evidências significativas da importância do pré-processamento de imagem bem escolhido para transferência de aprendizagem quando a quantidade de dados não é suficiente para ajustar a rede.

(MANINIS et al., 2016) propõem uma arquitetura de CNN básica DRIU, para segmentação de vasos retinianos e DOs que é rápido e preciso. A DRIU usa uma arquitetura de rede básica na qual dois conjuntos de camadas especializadas são treinados para resolver a separação do disco da retina e do disco óptico. Nos conjuntos de dados testados, DRIU apresenta resultados que não só têm um menor erro mediano, mas também mostram menos dispersão, portanto, mais consistência. Os resultados qualitativos corroboram que a DRIU é robusta e consistente, mesmo nos cenários mais desafiadores e diversos da base de dados RIM-ONE.

(YADAV; SARATHI; DUTTA, 2014) apresentam em seu método uma tentativa de estudar e analisar os recursos de textura em imagens no fundo de olho e suas variações quando a imagem apresenta incidência do glaucoma. As características de textura são

localizadas em torno do DO e extraídas com a matriz de co-ocorrência. O método de classificação proposto é o uso do classificador de rede neural com a ajuda da extração de características de textura da área localizada no DO das imagens do fundo de olho. O método de classificação de 72% de acurácia em classificar imagens normais ou glaucomatosas.

Diante do exposto nos trabalhos relacionados, o problema é trazer um diagnóstico mais completo, e torná-lo mais eficiente para que possa ser utilizado como sistema de diagnóstico auxiliado por computador, que ajudam a diminuir a variabilidade de interpretação, fornecendo uma segunda opinião ao especialista. Este trabalho tem como objetivo a utilização da *Deep Learning* para identificar ROIs de imagens da retina para serem posteriormente diagnosticadas quanto a presença do glaucoma.

3 Materiais e Métodos

Esta seção aborda a metodologia proposta neste trabalho para detecção, extração, e classificação de características do DO, a fim de diagnosticar automaticamente o glaucoma a partir de imagens digitais da retina.

A primeira etapa foi a aquisição de imagens, utilizando três bases de imagens públicas de fundo de olho. Em seguida, foram reunidas todas as imagens da retina, com olhos normais e em diferentes níveis de glaucoma para o treinamento da rede neural de aprendizado profundo. A rede utilizada é uma implementação da Rede Neural Convolutiva (CNN) baseada na arquitetura U-Net (RONNEBERGER; FISCHER; BROX, 2015), empregada com o objetivo de realizar o reconhecimento de padrões para detectar o DO.

Concluído o treinamento, é realizado com os pesos treinados da CNN a predição sobre as imagens de teste para segmentação da imagem, a fim de identificar a máscara com a ROI. Com a máscara da ROI definida, foi realizada a sobreposição da imagem testada com a máscara que a CNN detectou, para ter somente a região do DO a fim de facilitar a análise sobre as características da patologia e diminuir a região a ser processada. Em seguida foi realizada a extração dos vasos sanguíneos através de uma segmentação por limiar, pois os vasos não são relevantes para as próximas etapas de análise.

Após essa etapa, foi feita a extração de características na tonalidade de cinza das imagens, utilizando descritores de textura baseados em índices de diversidade filogenética. Por fim, foi realizada a classificação com um classificador baseado em CNN, para verificar a eficácia do método ao quantificar as imagens em normais ou glaucomatosas. Na Figura 1 tem-se o fluxograma que representa as etapas propostas na metodologia para diagnóstico do glaucoma.

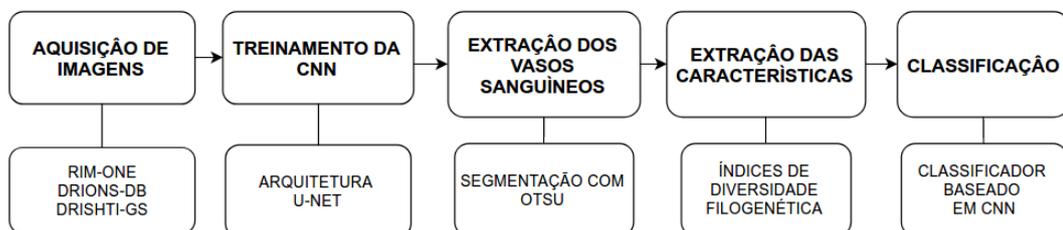


Figura 1: Fluxograma da metodologia proposta.

3.1 Aquisição de Imagens

Neste trabalho são utilizadas três bases de imagens da retina, a RIM-ONE (TRUCCO et al., 2013), a DRIONS-DB (CARMONA et al., 2008) e DRISHTI-GS (SIVASWAMY et al., 2014). Essas são bases de imagens públicas que foram dispostas para pesquisa, teste e desenvolvimento de soluções computacionais para auxílio ao diagnóstico do glaucoma. A base RIM-ONE possui 169 imagens sendo 119 de retinas normais, e as outras 51 com níveis diferentes do glaucoma, possuindo todas cinco marcações do DO para cada imagem. A base DRISHTI-GS contém 101 imagens, sendo que 50 delas apenas possuem a marcação do DO feito por especialistas. Já a base DRIONS-DB contém 110 imagens, as marcações do DO foram feitas por dois especialistas.

3.2 Convolutional Neural Network

Convolutional Neural Network é uma arquitetura de *Deep Learning*, sendo uma variação da rede neural artificial perceptron de múltiplas camadas, baseada no processamento de dados visuais, capaz de aplicar filtros nesses dados, mantendo a relação de vizinhança entre os *pixels* da imagem ao longo do processamento da rede (LECUN et al., 1998). O nome “*Convolutional Neural Network*” indica que a rede emprega uma operação matemática chamada convolução.

Em técnicas de *Deep Learning*, existem várias arquiteturas de CNNs, cada uma desenvolvida com um objetivo, seja classificação, como a GoogLeNet (SZEGEDY et al., 2015), detecção como VGG Net (SIMONYAN; ZISSERMAN, 2014), reconhecimento como AlexNet (KRIZHEVSKY; SUTSKEVER; HINTON, 2012), entre outras. Para tratar a primeira etapa do problema proposto, buscou-se utilizar uma arquitetura de CNN para segmentação de imagens. Para detecção do ROI, a imagem da retina tem que ser segmentada para separar o DO do restante da imagem. Para isso utilizou-se a arquitetura de CNN U-net, que tem atingido bons resultados em segmentação rápida e precisa de imagens médicas. Ela vem superando os métodos existentes em vários desafios biomédicos de segmentação de imagens (RONNEBERGER; FISCHER; BROX, 2015). A Figura 2 ilustra a arquitetura e as camadas que constituem a rede.

Como ilustrado na Figura 2, cada caixa azul corresponde a um mapa de recursos multicanal. A quantidade de canais é indicada no topo da caixa. O tamanho x-y é fornecido na margem inferior esquerda da caixa. As caixas brancas representam mapas de recursos copiados. As setas indicam as diferentes operações. No total, a rede possui 23 camadas convolutivas. Como algoritmo de otimização da rede, utilizou-se algoritmo *Adam*, pois é invariável ao redimensionamento diagonal dos gradientes e é adequado a grandes problemas em termos de dados.

A arquitetura consiste em dois caminhos, um de contratação (lado esquerdo) e o outro

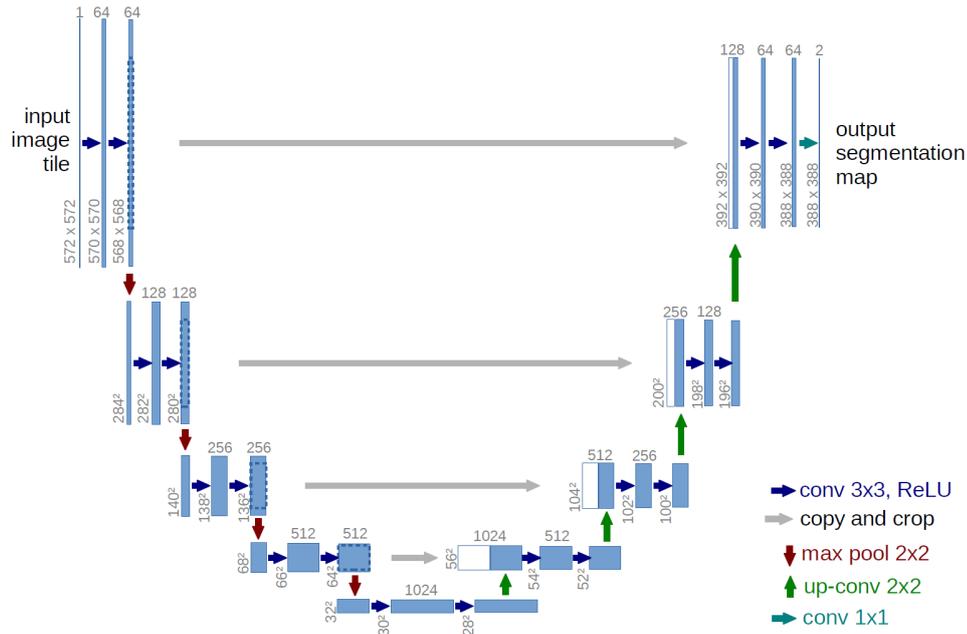


Figura 2: Representação da arquitetura U-net.

um caminho expansivo (lado direito). O caminho de contração segue a arquitetura típica de uma CNN. Consiste na aplicação repetida de duas convoluções 3x3, cada uma seguida por uma unidade linear retificada (ReLU) e uma operação de *max-pooling* de 2x2 com *stride 2* para *downsampling*. Em cada etapa de *downsampling* dobra-se o número de canais de recursos.

Cada passo no caminho expansivo consiste em um levantamento do mapa de recursos seguido de uma convolução 2x2 que faz a metade do número de canais de recursos, que é uma junção com o mapa de recursos correspondentemente cortado do caminho de contração e dois 3x3 circunvoluções, cada uma seguida por uma função de ativação uma ReLU. Essa etapa do caminho expansivo é necessário devido à perda de pixels de borda em cada convolução no caminho de contração. Na camada final é utilizada uma convolução 1x1 para mapear cada vetor de características de 64 componentes para o número desejado de classes.

3.3 Treinamento

Para o treinamento, os algoritmos foram desenvolvidos em linguagem de programação Python 3.5, e *framework* Keras (KERAS, 2017) para treinamento de redes neurais (com TensorFlow *backend* (ABADI et al., 2016)). A biblioteca OpenCV (BRADSKI; KAEHLER, 2008) foi usada para manipulação de imagens. A máquina utilizada contém hardware composto por processador Intel Core I5 64 bits, e 4GB de memória RAM DDR3.

Com a CNN implementada, o próximo passo e que merece muita atenção, é selecionar os dados de entrada para o treinamento da rede, pois são com eles que a CNN aprende.

Para isso, foram selecionadas aleatoriamente 326 imagens das três bases, sendo 155 da RIM-ONE, 51 da DRISHTI-GS, e 120 da DRIONS-DB, e separou-se 65 imagens para testes, sendo estas, também compostas por imagens das três bases e escolhidas aleatoriamente. Foram utilizadas imagens da retina e suas máscaras para o treinamento, pois as máscaras apontam as saídas desejadas sobre as imagens da retina, ou seja, a rede irá aprender a localizar o DO em imagens da retina.

(DOSOVITSKIY et al., 2014; MANINIS et al., 2016) relatam que redes neurais convolucionais são eficientes no aprendizado com uma grande quantidade de dados de entrada. Em posse dessa afirmação e observando o pequeno número de imagens disponíveis para treinamento, foi adotado como alternativa a rotação de cada uma das 326 imagens nos ângulos: 22, 45, 67, 90, 112, 135, 157, 202, 225, 247, 270, 290, 315, e 337 graus juntamente com suas máscaras, produzindo para cada imagem 14 novas imagens rotacionadas, resultando em 4564 imagens para treinamento. O treinamento realizado é a partir do zero, ou seja, nenhum modelo pré-treinado foi usado e os pesos dos filtros convolucionais foram iniciados aleatoriamente no início de cada treino.

Para a rede CNN aprender as características e padrões do DO, que é a região de interesse, foram passados como parâmetros de entrada as imagens da retina e suas devidas máscaras, sendo o papel da máscara apontar a classe que deve ser aprendida, que no caso é toda a estrutura do DO.

3.4 Extração dos Vasos Sanguíneos

Antes de extrair as características das imagens segmentadas com a CNN, retirou-se os vasos sanguíneos para facilitar a abstração de características relevantes para posterior classificação. Para isso, utilizou-se o algoritmo de segmentação por limiar de Otsu. Este algoritmo irá permitir-nos obter de forma rápida e automática o valor limite correto para escolher entre dois modos de histograma, permitindo-lhes aplicar o limiar de forma otimizada. Este algoritmo tenta encontrar um valor limiar (t) que minimiza a variância ponderada dentro da classe dada pela relação. Otsu binariza a imagem, como os vasos sanguíneos possuem uma tonalidade mais escura no DO, prevalece somente a região do DO sem os vasos, como mostra na equação 3.1.

$$\sigma_w^2(t) = q_1(t)\sigma_1^2(t) + q_2(t)\sigma_2^2(t) \quad (3.1)$$

Com isso, o algoritmo binariza a imagem, como os vasos sanguíneos possuem uma tonalidade mais escura no DO, prevalecendo somente a região do DO sem os vasos.

3.5 Extração de Características

A diversidade é um termo frequentemente usado em Ecologia. O objetivo de um índice de diversidade é descrever a variedade de espécies presentes em uma comunidade ou área (MAGURRAN, 2013). A filogenia é um campo de estudo da biologia para definir relações evolutivas em uma espécie, procurando determinar relações de ancestrais entre espécies conhecidas, a fim de conhecer a origem e o desenvolvimento das diversas espécies existentes no planeta (WEBB, 2000; HUELSENBECK et al., 2001). A diversidade filogenética estuda as diferentes espécies ou indivíduos em uma comunidade, incorporando de forma explícita as diferenças entre espécies usando a distância filogenética, a qual representa a magnitude das diferenças fenotípicas entre elas. A premissa principal dessa medida é que a diversidade é maior em uma comunidade em que as espécies são filogeneticamente mais distintas.

Para a extração de características das ROIs após a detecção do DO e extração das veias, utilizou-se os índices de diversidade filogenéticas *Phylogenetic Diversity* (PD), *Sum of Phylogenetic Distances* (SPD), *Mean Nearest Neighbour Distance* (MNND), *Phylogenetic Species Variability* (PSV) e *Phylogenetic Species Richness* (PSR) para extração de características baseadas em textura. Esses índices consideram a distância filogenética, calculada a partir da arquitetura da árvore filogenética.

Para isso, é feita uma analogia das propriedades da filogenia da biologia com as propriedades de uma imagem. O que representa uma comunidade na biologia, na metodologia vai representar uma ROI da imagem da retina. As espécies, são comparadas a quantidade de níveis de cinza. Os indivíduos, são representados como os pixels da imagem. E a distância filogenética é o número de arestas entre duas espécies. Assim são calculados os índices sobre as imagens para procurar e descrever essa relação filogenética, para posterior classificação.

O índice PD é o somatório dos comprimentos dos ramos da filogenia de cada espécie. Na Equação 3.2, o B é o número de ramificação da árvore, L_i é o comprimento do ramo e A_i é a abundância média de espécies que compartilham ramo i .

$$B \times \frac{\sum_i^B L_i A_i}{\sum_i^B A_i} \quad (3.2)$$

O SPD é a soma das distâncias filogenéticas entre cada par de espécies. O cálculo do SPD pode ser observado na Equação 3.3, onde d_{mn} é a distância entre as espécies m e n ; a_m é a abundância de espécies m ; S o número de espécies no conjunto focal.

$$\left(\frac{S(S-1)}{2} \right) \times \frac{\sum \sum_{m < n} d_{mn} a_m a_n}{\sum \sum_{m < n} a_m a_n} \quad (3.3)$$

O MNND é a distância média do táxon mais próximo. Na Equação 3.4, onde d_{mn} é a distância entre as espécies m e n ; a_m , abundância de espécies m .

$$\sum_m^S m i n (d_{mn}) a_m \quad (3.4)$$

O PSV é a variabilidade de espécies filogenéticas, que resume o grau em que as espécies em uma comunidade são filogeneticamente relacionadas. A variabilidade de espécies filogenéticas, resume o grau em que as espécies em uma comunidade são filogeneticamente relacionadas. O cálculo do PSV é definido na Equação 3.5, onde, o trC representa a soma dos valores da diagonal de uma matriz C , Σc é o somatório de todos os valores da matriz, n é o número de espécies e \bar{c} é a média dos elementos da diagonal de C .

$$PSV = \frac{ntrC - \Sigma c}{n(n-1)} = 1 - \bar{c} \quad (3.5)$$

E o PSR é a riqueza de espécies e quantifica o número de espécies em uma comunidade. A riqueza de espécies filogenéticas (PSR), quantifica o número de espécies em uma comunidade. O valor da riqueza de espécies filogenéticas é encontrado multiplicando-se o número de espécies n pela variabilidade da comunidade, pode-se verificar os parâmetros na Equação 3.6.

$$PSR = nPSV \quad (3.6)$$

3.6 Classificação

Para a classificação foi utilizada a suíte de algoritmos de mineração de dados, pré-processamento de dados, classificação, visualização, e aprendizado de máquina WEKA (*Waikato Environment for Knowledge Analysis*) (WEKA, 2017). Utilizou-se como classificador uma implementação baseada na última camada das CNNs, a *fully-connected*, sendo essa própria para trabalhar com números gerados pelos índices de diversidade filogenéticas (AMTEN, 2017). Esse classificador foi utilizado por além de classificar os resultados, aprende com os dados de treino, e utiliza esse aprendizado nos dados de teste, obtendo um bom resultado na categorização de padrões do DO.

3.7 Validação dos Resultados

Para validação dos resultados do método em quantificar o glaucoma em imagens de fundo de olho, utilizou-se de métricas de avaliação baseadas em estatística como Acurácia, Especificidade, Sensibilidade, Precisão, e Sobreposição (METZ, 1986; MARTINEZ; LOUZADA-NETO; PEREIRA, 2003).

4 Resultados e Discussões

Nesta seção são apresentados os resultados obtidos na metodologia proposta em classificar as imagens em glaucomatosas ou normais, com base nas imagens de teste. Em seguida, foi calculada a acurácia, sensibilidade, precisão, sobreposição e especificidade para cada teste, e por fim é feita a análise comparativa com outros trabalhos relacionados.

4.1 Configuração dos Testes

Para avaliar os resultados, foi realizado um teste selecionando aleatoriamente 14 imagens da base RIM-ONE e 51 da base DRISHTI-GS. Dentre elas, contém imagens da retina normais e com diferentes níveis de glaucoma, sendo que essas imagens não foram utilizadas para treinamento, somente para teste. Com isso desejava-se saber se após o treino, a CNN conseguiria identificar o DO em novas imagens da retina para garantir que a CNN aprendeu a reconhecer padrões do DO. Essas duas bases foram utilizadas para teste por terem a descrição identificando quem são imagens normais e glaucomatosas segundo os especialistas.

A base DRIONS-DB apresenta 23,1% das imagens glaucomatosas, entretanto, a mesma não indica quais imagens são, e por não disponibilizarmos de um médico para avaliar quais imagens de fato são portadoras do glaucoma, optamos por não utilizá-las na fase de teste. Como o objetivo do treinamento é deixar apta a CNN segmentar imagens da retina para detecção do DO, essa base foi utilizada por: a) a base contém a marcação ideal do DO feita por especialistas, na qual serve de saída desejada para treinamento. E b) as CNNs conseguem maior taxa de aprendizado com grandes quantidades de dados, sendo assim, a base DRIONS-DB possui novas e diferentes imagens em relação às outras bases. Esse fator faz com que a segmentação da CNN generalize o aprendizado para apontar a marcação ideal do DO em novas imagens, como também utilizado em (SEVASTOPOLSKY, 2017) para treinamento da CNN.

4.2 Resultados dos Testes

CNNs de classificação utilizam no final de suas arquiteturas uma camada totalmente conectada, na qual realiza a classificação sobre os dados das camadas anteriores, como feito nos trabalhos de (CHEN et al., 2015; ORLANDO et al., 2017), os quais realizam a etapa de classificação na mesma rede. Como o presente trabalho utilizou-se a arquitetura de CNN U-Net para realizar somente a segmentação precisa do DO, mas sem modifi-

car a arquitetura, a mesma não possui a camada totalmente conectada para trazer uma classificação sobre imagens glaucomatosas.

Na Figura 3, apresentam os resultados sobre as etapas para processamento da ROI. Na Figura 3(a) tem-se a imagem utilizada para teste. Na Figura 3(b) tem-se a predição feita pela CNN, realizando a segmentação sobre essa imagem, retornando a máscara apontando o DO. Na Figura 3(c) é ilustrado a sobreposição feita para ter a ROI isolada. Por fim, na Figura 3(d) ilustra a imagem resultante após a extração dos vasos sanguíneos.

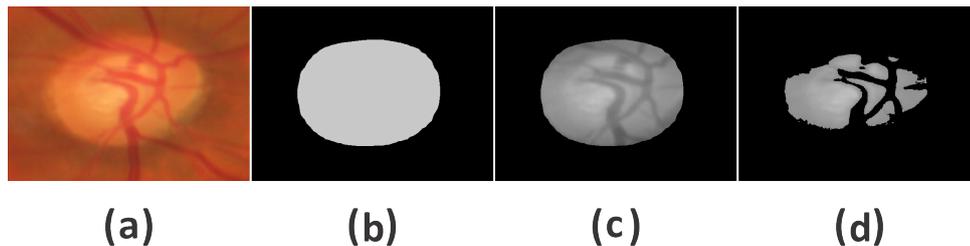


Figura 3: Detecção do DO.

Com os vasos sanguíneos extraídos, foram extraídas as características com descritores de textura. Para isso foram utilizados os índices de diversidade filogenética PD, SPD, MNND, PSV, PSR, com a finalidade de descrever informações a partir dos níveis de cinza da ROI. Em seguida foi realizada a classificação executando o WEKA com um classificador baseado em CNN, sobre as características extraídas das imagens. Tal classificador reconhece padrões sobre as informação extraídas pelos índices, distinguindo regiões e classificando imagens em normais ou doentes, trazendo um diagnóstico.

De acordo com as informações extraídas pelos índices, as ROIs das imagens normais apresentam características mais homogêneas em relação as ROIs das imagens glaucomatosas, que apresentam características heterogêneas devido as lesões, sendo a variabilidade de espécies, níveis de cinza, maior nas ROIs em imagens glaucomatosas. Os resultados obtidos na classificação foram promissores, o classificador da rede neural CNN atingiu uma acurácia de 98,5%, sensibilidade de 98,1%, especificidade de 100%, precisão de 100% e sobreposição de 93% em diagnosticar imagens normais e glaucomatosas.

Ao utilizar novas imagens da retina no método proposto, os resultados podem alcançar uma maior precisão na detecção do DO em diferentes amostras. Isso se deve ao fato que o núcleo do trabalho se baseia no aprendizado de máquina profundo, quanto mais amostras, maior a curva de aprendizado e precisão para reconhecimento dessas estruturas.

Em comparação com os trabalhos relacionados, como demonstra a Tabela 1, a metodologia se destacou. Os trabalhos de (SEVASTOPOLSKY, 2017; MANINIS et al., 2016) propuseram em suas metodologias o uso de técnicas de aprendizado profundo, com o uso de CNNs para detecção do DO, OC e vasos sanguíneos, mas as metodologias apenas trabalham na parte de segmentação das imagens de retina. Nos trabalhos de (CHEN et al., 2015; ORLANDO et al., 2017) os autores em suas metodologias vão além da segmenta-

Tabela 1: Comparação com os trabalhos relacionados

Trabalho	Base	A (%)
(SEVASTOPOLSKY, 2017)	RIN-ONE, DRIONS-DB, DRISHTI-GS	-
(CHEN et al., 2015)	ORIGA, SCES	-
(ORLANDO et al., 2017)	DRISHTI-GS1, DRIVE	-
(MANINIS et al., 2016)	DRIVE, STARE	-
(YADAV; SARATHI; DUTTA, 2014)	Privada	72
Metodologia	RIN-ONE, DRIONS-DB, DRISHTI-GS	98.5

ção, eles quantificam a patologia, mas a abordagem e valores dos resultados se diferem aos usados na metodologia proposta por a mesma utilizar os descritores baseados em textura para extrair características da imagens. No trabalho de (YADAV; SARATHI; DUTTA, 2014) os autores obtém 72% de acurácia na classificação do glaucoma, mas utilizam a matriz de concorrência para extrair características.

O referente trabalho se difere dos demais por utilizar uma metodologia mais completa e complexa para o diagnóstico do glaucoma, apresentando uma abordagem completa, automatizando o diagnóstico da patologia. A detecção do DO e OC para obter a relação do diâmetro da escavação e do disco (*cup-to-disk diameter ratio-CDR*), é indício para quantificar o glaucoma conforme relatado e empregado nos trabalhos relacionados. A metodologia proposta usou a CNN para detectar o DO e classificar as características, em que foram utilizados os descritores de textura para extrair as características do DO, com intuito de obter informações que quantifiquem a patologia com classificadores, sem necessidade então de detectar o CO e calcular o CDR.

5 Conclusão

Deep Learning é uma subárea da Inteligência Artificial que está em crescente avanço, inovando com o surgimento em aplicações de diversas técnicas e usos, impulsionando uma nova era de automatização inteligente. Com o uso de técnicas de PDI e IA, esse trabalho apresentou uma metodologia para detecção automática do DO em imagens da retina com CNN, utilizando descritores baseados em textura e o classificador CNN para discriminação e classificação de regiões em imagens da retina em glaucomatosas ou normais.

A análise de imagens da retina utilizando a ROI apresentou resultados eficientes na categorização de padrões de lesões glaucomatosas, atingindo uma taxa de acerto de 98.5% de acurácia, sensibilidade de 98,1%, especificidade de 100%, precisão de 100%, e sobreposição de 93% na quantificação do glaucoma. Assim, o referente trabalho tem uma maior relevância na área médica e computacional, pois com o uso dessas novas tecnologias, possibilitam ao profissional da área recursos para diagnosticar a doença fornecendo um diagnóstico mais precoce.

A partir dos resultados obtidos, pode-se inferir que a utilização da CNN para detecção da ROI, e descritores baseados na textura das regiões, apresentam resultados eficazes na classificação do quantificação do glaucoma. O uso de índices filogenéticos para descrever padrões em regiões de imagens mostrou-se eficiente para a metodologia proposta.

6 Publicações

FERREIRA, M. V. S.; CARVALHO FILHO, A. O.; SOUSA, A. D.; BARROS, P. V. S.; DRUMOND, P. M. L. L. Metodologia automática para diagnóstico do glaucoma usando abordagem Deep Learning. In: XIV ENIAC - Encontro Nacional de Inteligência Artificial e Computacional, 2017.

FERREIRA, M. V. S.; CARVALHO FILHO, A. O.; SOUSA, A. D.; BARROS, P. V. S.; DRUMOND, P. M. L. L. Diagnóstico Automático do Glaucoma usando Convolutional Neural Network e Descritores de Textura. In: X ENUCOMP - Encontro Unificado de Computação, 2017.

Referências

- ABADI, M. et al. Tensorflow: Large-scale machine learning on heterogeneous distributed systems. *arXiv preprint arXiv:1603.04467*, 2016. Citado na página 17.
- AGARWAL, A. et al. Automatic glaucoma detection using adaptive threshold based technique in fundus image. In: IEEE. *Telecommunications and Signal Processing (TSP), 2015 38th International Conference on*. [S.l.], 2015. p. 416–420. Citado na página 12.
- AMTEN, J. <https://github.com/amtan/NeuralNetwork>. 2017. Disponível em: <<https://github.com/amtan/NeuralNetwork>>. Citado na página 20.
- BRADSKI, G.; KAEHLER, A. *Learning OpenCV: Computer vision with the OpenCV library*. [S.l.]: "O'Reilly Media, Inc.", 2008. Citado na página 17.
- BURGOYNE, C. F. et al. The optic nerve head as a biomechanical structure: a new paradigm for understanding the role of iop-related stress and strain in the pathophysiology of glaucomatous optic nerve head damage. *Progress in retinal and eye research*, Elsevier, v. 24, n. 1, p. 39–73, 2005. Citado na página 12.
- CARMONA, E. J. et al. Identification of the optic nerve head with genetic algorithms. *Artificial Intelligence in Medicine*, Elsevier, v. 43, n. 3, p. 243–259, 2008. Citado na página 16.
- CHEN, X. et al. Glaucoma detection based on deep convolutional neural network. In: IEEE. *Engineering in Medicine and Biology Society (EMBC), 2015 37th Annual International Conference of the IEEE*. [S.l.], 2015. p. 715–718. Citado 4 vezes nas páginas 13, 21, 22 e 23.
- DOSOVITSKIY, A. et al. Discriminative unsupervised feature learning with convolutional neural networks. In: *Advances in Neural Information Processing Systems*. [S.l.: s.n.], 2014. p. 766–774. Citado na página 18.
- HUELSENBECK, J. P. et al. Bayesian inference of phylogeny and its impact on evolutionary biology. *science*, American Association for the Advancement of Science, v. 294, n. 5550, p. 2310–2314, 2001. Citado na página 19.
- KERAS. <https://keras.io/>. 2017. Disponível em: <<https://keras.io/about>>. Citado na página 17.
- KRIZHEVSKY, A.; SUTSKEVER, I.; HINTON, G. E. Imagenet classification with deep convolutional neural networks. In: *Advances in neural information processing systems*. [S.l.: s.n.], 2012. p. 1097–1105. Citado na página 16.
- LAMANI, D. et al. Early detection of glaucoma through retinal nerve fiber layer analysis using fractal dimension and texture feature. *International Journal of Research in Engineering and Technology*, 2014. Citado na página 12.
- LECUN, Y. et al. Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, IEEE, v. 86, n. 11, p. 2278–2324, 1998. Citado na página 16.

- LIU, J. et al. Automatic glaucoma diagnosis from fundus image. In: IEEE. *Engineering in Medicine and Biology Society, EMBC, 2011 Annual International Conference of the IEEE*. [S.l.], 2011. p. 3383–3386. Citado na página 12.
- MAGURRAN, A. E. *Measuring biological diversity*. [S.l.]: John Wiley & Sons, 2013. Citado na página 19.
- MANINIS, K.-K. et al. Deep retinal image understanding. In: SPRINGER. *International Conference on Medical Image Computing and Computer-Assisted Intervention*. [S.l.], 2016. p. 140–148. Citado 4 vezes nas páginas 13, 18, 22 e 23.
- MARTINEZ, E. Z.; LOUZADA-NETO, F.; PEREIRA, d. B. B. A curva roc para testes diagnósticos. *Cad Saúde Coletiva*, v. 11, n. 1, p. 7–31, 2003. Citado na página 20.
- METZ, C. E. Roc methodology in radiologic imaging. *Investigative radiology*, LWW, v. 21, n. 9, p. 720–733, 1986. Citado na página 20.
- OLIVEIRA, F. S. S. de et al. Classification of breast regions as mass and non-mass based on digital mammograms using taxonomic indexes and svm. *Computers in biology and medicine*, Elsevier, v. 57, p. 42–53, 2015. Citado na página 12.
- ORLANDO, J. I. et al. Convolutional neural network transfer for automated glaucoma identification. In: INTERNATIONAL SOCIETY FOR OPTICS AND PHOTONICS. *12th International Symposium on Medical Information Processing and Analysis*. [S.l.], 2017. p. 101600U–101600U. Citado 4 vezes nas páginas 13, 21, 22 e 23.
- RONNEBERGER, O.; FISCHER, P.; BROX, T. U-net: Convolutional networks for biomedical image segmentation. In: SPRINGER. *International Conference on Medical Image Computing and Computer-Assisted Intervention*. [S.l.], 2015. p. 234–241. Citado 3 vezes nas páginas 12, 15 e 16.
- SEVASTOPOLSKY, A. Optic disc and cup segmentation methods for glaucoma detection with modification of u-net convolutional neural network. *arXiv preprint arXiv:1704.00979*, 2017. Citado 4 vezes nas páginas 13, 21, 22 e 23.
- SIMONYAN, K.; ZISSERMAN, A. Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*, 2014. Citado na página 16.
- SIVASWAMY, J. et al. Drishti-gs: Retinal image dataset for optic nerve head (onh) segmentation. In: IEEE. *Biomedical Imaging (ISBI), 2014 IEEE 11th International Symposium on*. [S.l.], 2014. p. 53–56. Citado na página 16.
- SZEGEDY, C. et al. Going deeper with convolutions. In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. [S.l.: s.n.], 2015. p. 1–9. Citado na página 16.
- TRUCCO, E. et al. Validating retinal fundus image analysis algorithms: Issues and a proposal validating retinal fundus image analysis algorithms. *Investigative ophthalmology & visual science*, The Association for Research in Vision and Ophthalmology, v. 54, n. 5, p. 3546–3559, 2013. Citado na página 16.
- WEBB, C. O. Exploring the phylogenetic structure of ecological communities: an example for rain forest trees. *The American Naturalist*, The University of Chicago Press, v. 156, n. 2, p. 145–155, 2000. Citado na página 19.

WEKA. Machine learning group at the university of waikato. 2017. Disponível em: <<http://www.cs.waikato.ac.nz/ml/weka/>>. Citado na página 20.

YADAV, D.; SARATHI, M. P.; DUTTA, M. K. Classification of glaucoma based on texture features using neural networks. p. 109–112, 2014. Citado 3 vezes nas páginas 12, 13 e 23.

YIN, F. et al. Automated segmentation of optic disc and optic cup in fundus images for glaucoma diagnosis. In: IEEE. *Computer-based medical systems (CBMS), 2012 25th international symposium on*. [S.l.], 2012. p. 1–6. Citado na página 12.



**TERMO DE AUTORIZAÇÃO PARA PUBLICAÇÃO DIGITAL NA BIBLIOTECA
“JOSÉ ALBANO DE MACEDO”**

Identificação do Tipo de Documento

- () Tese
() Dissertação
() Monografia
(X) Artigo

Eu, **Marcos Vinícius dos Santos Ferreira**, autorizo com base na Lei Federal nº 9.610 de 19 de Fevereiro de 1998 e na Lei nº 10.973 de 02 de dezembro de 2004, a biblioteca da Universidade Federal do Piauí a divulgar, gratuitamente, sem ressarcimento de direitos autorais, o texto integral da publicação **Metodologia automática para diagnóstico do glaucoma usando abordagem *Deep Learning*** de minha autoria, em formato PDF, para fins de leitura e/ou impressão, pela internet a título de divulgação da produção científica gerada pela Universidade.

Picos-PI 09 de Janeiro de 2017.

Marcos Vinícius dos Santos Ferreira

Assinatura